

一般セッション | 公募セッション：一般セッション

2024年3月5日(火) 13:45 ~ 17:05 総合科学部 2階 K207(広島大学 東広島キャンパス)

**[N-1] 非線形問題**

座長:山仲 芳和(宇都宮大学)、神野 健哉(東京都市大学)

13:45 ~ 14:00

[N-1-01]

時空間学習則におけるシナプス重み空間と出力空間との関係のユークリッド距離を用いた定性的評価

○織間 健守<sup>1</sup>、堀尾 喜彦<sup>1</sup>、辻 孟<sup>1</sup>、古谷 守<sup>1</sup> (1. 東北大)

14:00 ~ 14:15

[N-1-02]

時間履歴項を持つ出力層ニューロンを用いたニューラルネットワークリザバーによる時系列予測

○佐野 光希<sup>1</sup>、堀尾 喜彦<sup>1</sup>、織間 健守<sup>1</sup>、石井 豪<sup>1</sup> (1. 東北大)

14:15 ~ 14:30

[N-1-03]

インバータ電源で構成される配電システムの可到達性解析

○谷口 太郎<sup>1</sup>、薄 良彦<sup>1</sup> (1. 京都大学)

14:30 ~ 14:45

[N-1-04]

リザーバコンピューティングを用いた間欠性カオスにおける非線形ダイナミクスの調査

○小原 翔馬<sup>1</sup>、菅野 円隆<sup>2</sup>、内田 淳史<sup>2</sup>、黒川 弘章<sup>1</sup> (1. 東京工科大、2. 埼玉大)

14:45 ~ 15:00

[N-1-05]

簡素なデジタルマップの周期軌道について

○山口 峰世<sup>1</sup>、鯨井 慎也<sup>1</sup>、齋藤 利通<sup>1</sup> (1. 法政大学)

15:00 ~ 15:15

[N-1-06]

並列化降圧コンバータの2目的最適化について

○澁谷 晃誠<sup>1</sup>、沼田 龍之介<sup>1</sup>、飯塚 寛人<sup>1</sup>、齋藤 利通<sup>1</sup> (1. 法政大)

15:15 ~ 15:30

[N-1-07]

分岐増幅器を用いたシフトレジスタの提案

○田中 宏哉<sup>1</sup>、田所 幸浩<sup>1</sup> (1. 豊田中研)

15:30 ~ 15:35

休憩時間

15:35 ~ 15:50

[N-1-08]

アイトラッカーの欠損値を用いた注意欠陥・多動性障害の瞬き頻度の分析

○上野 歩<sup>1</sup>、関口 雅也<sup>1</sup>、信川 創<sup>1,2</sup>、白間 綾<sup>2</sup>、高橋 哲也<sup>3</sup>、戸田 重誠<sup>3,4</sup> (1. 千葉工業大学、2. 国立研究開発法人 国立精神・神経医療研究センター、3. 金沢大学、4. 昭和大学)

---

◆ 学術奨励賞候補 ◆ キャリアエクスプローラー

15:50 ~ 16:05

[N-1-09]

離散力学系より得られる時系列データおよびパラメータを学習したExtreme learning machineに基づく分岐解析手法

○加藤 海渡<sup>1</sup>、伊藤 佳卓<sup>2</sup>、高坂 拓司<sup>1</sup> (1. 中京大、2. 北海道科学大)

---

◆ 学術奨励賞候補

16:05 ~ 16:20

[N-1-10]

Hebb 則と時空間学習則のパターン分離能力の比較

○塚本 陽太<sup>1</sup>、塚田 啓道<sup>2</sup>、塚田 稔<sup>3</sup>、池口 徹<sup>1</sup> (1. 東京理科大学、2. 中部大学 AI数理データサイエンスセンター、3. 玉川大学 脳科学研究所)

---

16:20 ~ 16:35

[N-1-11]

カオスニューロダイナミクスを用いた切替機構の隠れマルコフモデルへの置換

○橋 俊宏<sup>1</sup>、安達 雅春<sup>2</sup> (1. 湘南工科大学、2. 東京電機大学)

---

◆ 学術奨励賞候補

16:35 ~ 16:50

[N-1-12]

ヒステリシスリザーバーコンピューティングの内部設計と性能向上

○横山 賢太<sup>1</sup>、神野 健哉<sup>1</sup> (1. 東京都市大学)

---

16:50 ~ 17:05

[N-1-13]

画像式光電脈波のデータ縮小が予測可能性に及ぼす影響

○古賀 滉大<sup>1</sup>、スヴィリドヴァ ニーナ<sup>1,2</sup> (1. 東京都市大、2. 東京大学国際高等研究所ニューロインテリジェンス国際研究機構)

---

# 時空間学習則におけるシナプス重み空間と出力空間との関係のユークリッド距離を用いた定性的評価

Qualitative Evaluation of the Relationship between Synaptic Weight Space and Output Space  
in Spatio-Temporal Learning Rule Using Euclidean Distance

織間健守<sup>1</sup>  
Takemori Orima

堀尾喜彦<sup>1,2,3</sup>  
Yoshihiko Horio

辻孟<sup>1,2</sup>  
Takeru Tsuji

古谷守<sup>1,3</sup>  
Mamoru Furuya

東北大学 電気通信研究所<sup>1</sup>  
RIEC, Tohoku University

東北大学大学院 情報科学研究科<sup>2</sup>  
GSIS, Tohoku University

東北大学 工学部<sup>3</sup>  
School of Engineering, Tohoku University

## 1 まえがき

時空間学習則は、海馬の生理学実験を基に提案された学習則である [1]。海馬は、学習する時空間パターンの文脈構造をネットワーク内のシナプス重み空間へ自己相似構造として記憶すると示唆されている [2]。我々は、シナプス重み空間に埋め込まれた情報を出力空間で読み出す手法を提案した [3]。しかし、読み出された情報とシナプス重み空間に記憶された情報との関係は、明らかになっていない。そこで、本研究では、学習した時空間パターンごとに得られた各シナプス重み行列間のユークリッド距離を二次元マップとして表示する。一方、ある読み出し信号を入力した時の各出力ベクトル間のユークリッド距離を用いた二次元マップも作成する。これらの比較により、シナプス空間上に埋め込まれた記憶と出力空間上に表出した情報の対応関係を定性的に評価する。

## 2 シナプス重み行列と出力ベクトル

ニューロン数  $N = 120$  の単層フィードフォワードニューラルネットワークを用いる [3]。各ニューロンは、入力数  $M = 120$  と同数のシナプスを持ち、入力に対して全結合である。ネットワーク内の各シナプス重みの値は、時空間学習則 [1] により更新される。以下では、互いにハミング距離が 10 である 4 種類の  $M$  次元の空間ベクトルを、時間方向に並べ替えて生成された  $24 (= 4!)$  通りの時空間パターンを学習する。 $k$  番目の時空間パターンを学習して得られたシナプス重み行列と出力ベクトルを、それぞれ、次式に示す。

$$\mathbf{w}^k = \begin{bmatrix} w_{11}^k & \cdots & w_{1j}^k & \cdots & w_{1M}^k \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ w_{i1}^k & & w_{ij}^k & & w_{iM}^k \\ \vdots & & \vdots & \ddots & \vdots \\ w_{N1}^k & \cdots & w_{Nj}^k & \cdots & w_{NM}^k \end{bmatrix} \quad (1)$$

$$\mathbf{y}^k = [y_1^k \ \cdots \ y_i^k \ \cdots \ y_N^k]^\top \quad (2)$$

ここで、 $w_{ij}^k$  は、 $i$  番目のニューロンが持つ  $j$  番目のシナプス重み、 $y_i^k$  は、ある読み出し信号を入力して得られた  $i$  番目のニューロン出力である。また、 $\top$  は、転置を表す。

## 3 シナプス重み空間と出力空間との関係

$k$  および  $l$  番目の時空間パターンを学習した 2 つのネットワークの、それぞれのシナプス重み行列  $\mathbf{w}^k$  および  $\mathbf{w}^l$  間のユークリッド距離  $ED_w(k, l) = \|\mathbf{w}^k - \mathbf{w}^l\|_2$  と、それぞれに同じ読み出し信号を入力して得られた出力ベクトル  $\mathbf{y}^k$  および  $\mathbf{y}^l$  間のユークリッド距離  $ED_y(k, l) = \|\mathbf{y}^k - \mathbf{y}^l\|_2$  を求める。これを  $1 \leq k \leq 24$  および  $1 \leq l \leq 24$  の全ての組合せについて行い、得られた値を図 1 のように二次元マップとして表示する。 $ED_w(k, l)$  を用いた図 1(a) において、シナプス重み空間上に記憶された情報の自己相似構造が確認できる。一方、図 1(b) に示す  $ED_y(k, l)$  を用いた二次元マップでも、これと同様な構造が確認できる。

## 4 まとめ

シナプス重み空間に記憶された情報が読み出し信号によって出力空間に表出することを明らかにした。今後は、シナプス重み空間上での記憶の埋め込みに関する詳細な検討を行う。




図 1 (a)  $\mathbf{w}^k$  および  $\mathbf{w}^l$  間の  $ED_w(k, l)$  の二次元マップ、(b)  $\mathbf{y}^k$  および  $\mathbf{y}^l$  間の  $ED_y(k, l)$  の二次元マップ。

本研究は JSPS 科研費 20H00596、21K18303、23K19991、JST CREST JPMJCR19K3、および東北大学電気通信研究所共同プロジェクト研究の助成を受けたものです。

## 参考文献

- [1] M. Tsukada and X. Pan, Bio. Cybern., vol. 92, no. 2, pp. 139–146, 2005.
- [2] 津田一郎, 応用数理, vol. 18, no. 3, pp. 176–193, 2008.
- [3] T. Tsuji et al., in Proc. NOLTA, pp. 415–418, 2023.

# 時間履歴項を持つ出力層ニューロンを用いた ニューラルネットワークリザーバーによる時系列予測

Time-Series Prediction by Neural Network Reservoir Using Output Layer Neuron with Temporal-History Terms

佐野 光希<sup>1,2</sup>

Teruki Sano

堀尾 喜彦<sup>1,2,3</sup>

Yoshihiko Horio

織間 健守<sup>1</sup>

Takemori Orima

石井 豪<sup>1,3</sup>

Gou Ishii

東北大学 電気通信研究所<sup>1</sup>  
RIEC, Tohoku University

東北大学 工学部<sup>2</sup>  
School of Engineering, Tohoku University

東北大学大学院 情報科学研究科<sup>3</sup>  
GSIS, Tohoku University

## 1 まえがき

時間履歴項を持つ出力層ニューロンを用いたニューラルネットワークリザーバー (NNR) を提案する. 本稿では, 時間履歴項を持つニューロンの一例として, 拡張カオスニューロンモデル [1]を用いる.

## 2 出力層に時間履歴項を持つニューロンを用いた NNR

$N$  個のニューロンから成るリザーバー層内の,  $i$  番目のニューロンの離散時刻  $n$  での内部状態  $x_i^R(n)$  と出力  $y_i^R(n)$  が, それぞれ以下で与えられる NNR を考える [2].

$$x_i^R(n+1) = w_i^I u^I(n+1) + \sum_{j=1}^N w_{ij}^R y_j^R(n) + \theta, \quad (1)$$

$$y_i^R(n+1) = f(x_i^R(n+1)), \quad (2)$$

$$f(z) = \tanh(z). \quad (3)$$

ここで,  $u^I(n)$  は入力信号,  $w_i^I$  および  $w_{ij}^R$  は, それぞれ,  $i$  番目のニューロンに対する入力重み, および, リザーバー層内の  $j$  番目のニューロンとの間の結合重み,  $f(\cdot)$  は出力関数,  $\theta$  は外部バイアスであり, 以下では  $N = 400$  とする.

一方, 出力層ニューロンとして, カオスニューロンモデルに基づく以下のニューロンモデルを導入する [3].

$$x(n+1) = \sum_{h=1}^N w_h y_h^R(n+1) + \gamma x(n) + \delta y(n), \quad (4)$$

$$y(n+1) = f(x(n+1)). \quad (5)$$

ここで,  $x(n)$  および  $y(n)$  は, それぞれ, 内部状態および出力,  $w_h$  は  $h$  番目のリザーバー層のニューロンからの結合重み,  $\gamma$  および  $\delta$  は, それぞれ, 内部状態および出力の時間履歴のパラメータであり, それらの取りうる値を  $-1 \leq \gamma, \delta \leq 1$  のように拡張する.

## 3 時系列信号予測

次式の Mackey-Glass システムから得られる時系列の  $M$  ステップフリーラン予測を行う.

$$u^I(n+1) = u^I(n) + \Delta t \left( \frac{0.2u^I(n-T)}{1+u^I(n-T)^{10}} - 0.1u^I(n) \right), \quad (6)$$

$$T = \tau / \Delta t. \quad (7)$$

ここで,  $\tau, \Delta t$  および  $T$  は, それぞれ, 元の微分方程式中の遅れ時間, 数値積分の刻み幅, 近似差分方程式中での

遅れ時間であり,  $\tau = 17, \Delta t = 0.1\tau$  および  $T = 10$  とする. また, 次式の時系列を教師信号とする.

$$y^{\text{teach}}(n) = u^I(n+M) - 1. \quad (8)$$

ただし,  $M = 10$  であり,  $\gamma$  と  $\delta$  の値を  $-1 \leq \gamma, \delta \leq 1$  の範囲で変化させ, 各パラメータについて 2000 ステップ学習を行う. 学習後に,  $u^I(n) = y(n-M)$  としたフリーラン予測を行い, 次式の誤差を評価する.

$$\text{MSE}(L) = \frac{1}{L} \sum_{k=1}^L (y(k) - y^{\text{teach}}(k))^2. \quad (9)$$

ここで,  $k$  はフリーラン開始からの時刻,  $L$  はフリーランのステップ数である.

各  $\gamma, \delta$  に対する結果を図 1 に示す. 図 1(a) 中,  $\gamma = \delta = 0$  の点線の四角は従来モデルを示す. また実線の四角は提案モデルで  $\text{MSE}(500)$  が最小となるパラメータを示す. 図 1(b) より, 提案モデルは  $L = 500$  において, 従来モデルと比較して最大 70 倍予測性能が向上し, 長いフリーランステップ数でも精度を保っていることが分かる.




図 1 従来モデルと提案モデルの予測誤差の比較. (a) 各  $\gamma, \delta$  に対する  $\text{MSE}(500)$ , (b) フリーランのステップ数  $L$  に対する  $\text{MSE}(L)$  の変化.

## 4 まとめ

時間履歴項を持つ出力層ニューロンとして, 拡張カオスニューロンモデルを用いた NNR を提案し, 時系列予測実験により, 提案手法の有効性を確認した. 今後は, 様々な時系列に対する予測を通して, 時間履歴項の影響を解明する.

本研究は, JSPS 科研費 20H00596, 21K18303, および, 東北大学電気通信研究所共同研究プロジェクトの助成を受けた.

## 参考文献

- [1] 石井 豪 他, 日本神経回路学会 第 31 回全国大会, 2023.
- [2] H. Jaeger, Tech. Rep. GMD, 148, 2001.
- [3] 藤井香之介 他, 信学総大, N-1-15, p. 214, 2023.

# インバータ電源で構成される配電システムの可到達性解析

Reachability Analysis of a Power Distribution System Consisting of Inverter-Based Resources

谷口太郎  
Taro Taniguchi

薄良彦  
Yoshihiko Susuki

京都大学 工学部 電気電子工学科  
School of Electrical and Electronic Engineering, Kyoto University

**1 はじめに** 近年、再生可能エネルギーの大量導入に伴い、Inverter-Based Resources (IBR) の普及が進んでいる [1]. IBR は物理的慣性を持たないため、IBR で構成される電力システムは従来の回転機からなるシステムとは異なるダイナミクスを有する [1]. 本報告では、IBR からなるシステムの動特性の解析を目標に、Droop 制御 [2,3,4] された IBR からなる配電システムの動特性に対して、可到達集合 [5,6] を用いた解析を行う。

**2 配電システムのモデル** Fig. 1 に対象とする配電システムのモデルを示す。2 台の Droop 制御されたインバータ電源が配電フィードを介して配電用変電所に連系されている。このとき、配電システムのダイナミクスは、電源の位相角  $\delta_i$  および電圧振幅  $v_i$  ( $i = 1, 2$ ) を従属変数とする微分方程式 Eq. (1) で表される [3].

$$\begin{cases} \dot{\delta}_i = K_{ai}(-\delta_i + \delta_i^*) + m_i(p_i^* - p_i) \\ \dot{v}_i = K_{ei}(-v_i + v_i^*) + n_i(q_i^* - q_i) \end{cases} \quad (1)$$

ここで  $m_i, n_i$  は Droop ゲイン、 $K_{ai}, K_{ei}$  は応答を高速化させる設計可能なゲインである。また、 $\delta_i^*, v_i^*$  は  $\delta_i, v_i$  の目標値であり、本報告ではこの近傍をターゲット集合に取る。本検討では、簡単のため、 $K_{ei}$  を十分に大きくとり、 $v_1$  の収束が速く  $v_1^*$  で一定であるとしている。なお、 $p_1, p_2, q_2$  は、電源から配電システムへ流入する有効電力、無効電力であり、潮流計算により以下で与えられる ( $G_i, B_i$  はそれぞれフィードのコンダクタンス行列とサセプタンス行列の成分である)[3].

$$\begin{cases} p_1 = v_1^2 G_1 - v_1^* G_1 \cos \delta_1 - v_1^* B_1 \sin \delta_1 + v_1^2 G_2 \\ \quad - v_1^* v_2 G_2 \cos(\delta_1 - \delta_2) - v_1^* v_2 B_2 \sin(\delta_1 - \delta_2) \\ p_2 = v_2^2 G_2 - v_1^* v_2 G_2 \cos(\delta_2 - \delta_1) \\ \quad - v_1^* v_2 B_2 \sin(\delta_2 - \delta_1) \\ q_2 = -v_2^2 B_2 + v_1^* v_2 B_2 \cos(\delta_2 - \delta_1) \\ \quad - v_1^* v_2 G_2 \sin(\delta_2 - \delta_1) \end{cases} \quad (2)$$

また、Eq. (1) の  $P_1^*, P_2^*, Q_2^*$  は目標値に相当する電源からの流入電力である。




Figure 1: Power distribution system.




Figure 2: Target set.




Figure 3: Reachset at  $t = 0.15$  s.




Figure 4: Reachset at  $t = 0.25$  s.




Figure 5: Number of grids of reachset.

**3 可到達集合の計算結果** 本報告では、[3] のパラメータを参考に、 $K_{a1}, K_{a2}, K_{e2}$  を 10, Droop ゲインを  $m_1 = 0.1, m_2 = 0.1, n_2 = 0.1$  とした場合の可到達集合を計算する。計算する領域 (計算領域) は  $\delta_1, \delta_2$  が  $[-7.5, 7.5]$ ,  $v_2$  が  $[0, 5]$  の空間であり、この空間内に  $50 \times 50 \times 50$  のグリッドをとる。時間は  $0$  s から  $0.35$  s の範囲で計算する。計算には MATLAB で使用できる関数群 ToolboxLS [7] を用いた。

Fig. 2 から Fig. 4 はそれぞれ、 $t = 0$  s (ターゲット集合)、 $t = 0.15$  s、 $t = 0.25$  s における可到達集合を表す。また、Fig. 5 は、計算領域全体に対する可到達集合の割合の時間発展を示す。Fig. 5 からわかるように  $0.32$  s 後には計算領域全体が可到達集合内に入る。可到達集合を用いることで、Eq. (1) の系について、安定平衡点へ収束する領域の時間発展を計算できる。この解析手法は、IBR からなる配電システムの吸引領域に対して過渡的な解析が可能であり、ダイナミクスを陽に考慮したゲインなどのパラメータの設計問題への応用が期待できる。

**謝辞** 本研究の遂行にあたりサポートを頂きました引原隆士先生にお礼申し上げます。

**文献** [1] A. Ulbig, T.S. Borsche, and G. Andersson, IFAC Proceedings Volumes, vol.47, no.3, pp.7290–7297, 2014. [2] J. W. Simpson-Porco, F. Dörfler, and F. Bullo, IEEE Transactions on Automatic Control, vol.62, no.3, pp.1239–1253, 2017. [3] H. Moussa, A. Shahin, et al, 2015 IEEE ECCE, pp.506–511, 2015. [4] Q.-C. Zhong and T. Hornik, Parallel operation of inverters (Wiley-IEEE Press, 2012) pp. 297–333. [5] 引原隆士, 平成 17 年電気学会全国大会, vol.6, p.187, 2005. [6] 例えば, S. Bansal, M. Chen, et al., Proc. 2017 IEEE 56th Annual Conference on Decision and Control (CDC), pp.2242–2253, 2017. [7] I.M. Mitchell, J. Sci. Comput., vol.35, pp.300–329, 2008.

# リザーバコンピューティングを用いた間欠性カオスにおける非線形ダイナミクスの調査

Study on nonlinear dynamics of intermittent chaos using reservoir computing

小原 翔馬<sup>1</sup>  
Shoma Ohara

菅野 円隆<sup>2</sup>  
Kazutaka Kanno

内田 淳史<sup>2</sup>  
Atsushi Uchida

黒川 弘章<sup>1</sup>  
Hiroaki Kurokawa

東京工科大学 工学部<sup>1</sup>  
Department of Electrical and Electronic Engineering,  
Tokyo University of Technology

埼玉大学 理工学研究科<sup>2</sup>  
Department of Information and Computer Sciences,  
Saitama University

## 1 はじめに

戻り光を有する半導体レーザにおける非線形ダイナミクスは様々な振る舞いを示す。その一種に間欠性カオスがある。間欠性カオスは振幅の小さなラミナー状態と、突発的かつ急激な振幅増加が生じるバーストから構成され、2つの状態が混在しているダイナミクスである。半導体レーザの間欠性カオスに関して、発生メカニズムに関する研究が報告されている [1]。半導体レーザにおける間欠性カオスは、ラミナー状態とバースト状態のそれぞれで局所的なアトラクタを有し、ラミナー状態のアトラクタからバーストのアトラクタへ遷移することでバーストが発生する。

また近年、機械学習の新たな手法としてリザーバコンピューティングが注目されている。リザーバコンピューティングは、リカレントニューラルネットワークの一種であり時系列予測に有用な手法であることが知られている [2]。これまでに、リザーバコンピューティングを用いて、戻り光を有する半導体レーザの間欠性カオスにおいて、レーザの出力強度を学習することによりバーストの発生を予測する研究が行われている [3]。

そこで本研究では、リザーバコンピューティングを用いて戻り光を有する半導体レーザの間欠性カオスにおける時系列予測を行うことにより、バーストの発生の予測において、アトラクタが遷移する際の重要な特徴を明らかにする。

## 2 方法と結果

本研究では、リザーバコンピューティングの代表的モデルである Echo State Network を用いて時系列予測を行う。また、戻り光を有する半導体レーザのレート方程式である Lang-Kobayashi 方程式 [4] を用いることにより、間欠性カオスを発生させる。このレーザの出力強度、光周波数シフト、キャリア密度の3変数の情報を入力信号として用いて時系列予測を行う。本研究ではレーザの時系列を20万点用意し、そのうちの16万点を学習用データ、残りの4万点をテストデータとして用いる。

リザーバコンピューティングを用いて間欠性カオスの1点先の時系列予測を行った結果を Fig.1 に示す。Fig.1 は、テストの4万点における予測結果の出力から構成されたアトラクタであり、アトラクタ上の線は、ラミナーからバーストへ遷移する20ステップ分(境界の前後10

ステップ)の入力信号と予測信号の軌道を示している。予測信号は、入力信号を精度良く再現出来ており、ラミナーからバーストへ遷移する軌道を明確に表せている。このことから、バーストが発生する1点前までの情報があれば、バーストの発生の予測が可能であることが分かる。




Fig. 1 Trajectories of input and prediction signal when the burst occurs on the attractor for prediction signal.

## 3 まとめ

本研究では、リザーバコンピューティングを用いて間欠性カオスの時系列予測を行い、バーストへの遷移を観測した。その結果、入力信号を精度良く予測し、バーストへの遷移が発生する軌道を観測することが出来た。少なくともバーストが発生する1点前までのラミナーの情報を利用すれば、バーストの発生の予測が可能であることが分かった。今後の課題として、さらに遠い点の予測を行い、どの時点までの情報があればリザーバはバーストの発生を予測できるか調査する。

## 参考文献

- [1] A. Karsaklian Dal Bosco, et al., Opt. Express, **24**, 22198 (2016).
- [2] L. Appeltant, et al., Nat. Commun, **2**, 468 (2011).
- [3] S. Ohara, et al., Proc. NOLTA2023, 625 (2023).
- [4] R. Lang, and K. Kobayashi, IEEE Journal of Quantum Electronics, **16**, 347 (1980).

# 簡素なデジタルマップの周期軌道について

On Binary Periodic Orbits in Simple Digital Maps

山口 峰世<sup>1</sup>                      鯨井 慎也<sup>1</sup>                      齋藤 利通<sup>1</sup>  
Hosei Yamaguchi                      Shinya Kujirai                      Toshimichi Saito

法政大学 理工学部 電気電子工学科<sup>1</sup>  
Electrical and Electronics Department, Faculty of Science and Engineering, Hosei University

## 1 はじめに

様々な周期軌道を呈するデジタルマップを簡素な特徴量を用いて解析する。

## 2 本論

デジタルマップ (Dmap) は、点の集合で定義されるデジタル力学系である。初期値とパラメータに依存し、様々な周期軌道を呈する。定義域が有限の点からなるため、定常状態では必ず周期軌道となる [1] [2]。本稿では、カオスを呈するカットマップを離散化して得られる Dmap の動作を考察する。カットマップは次式で記述される：

$$x_{n+1} = f(x_n) = \begin{cases} ax_n & \text{for } 0 \leq x_n < 1/2 \\ ax_n - 1 & \text{for } 1/2 \leq x_n < 1 \end{cases} \quad (1)$$

ただし、 $x_n$  は離散時刻  $n$  での状態変数であり、パラメータは  $0 \leq x_n < 1$ ,  $1.5 \leq a < 2.0$  である。これを  $N$  個の点で離散化すると、Dmap が得られる：

$$x_{n+1} = g(f(x_n)) = \frac{1}{N} \text{INT}(N \cdot x_n + 1/2) \quad (2)$$

状態変数は離散化され、 $x_n \in \{0, \dots, (N-1)/N\} \equiv \{C_0, \dots, C_{2N-1}\}$  となる。図 1 に Dmap の例を示す。

Dmap の周期軌道を解析するために、いくつかの定義をあたえる。ある点  $p$  が  $f^k(p) = p$  であり、 $f^l(p) \neq p$  ( $0 < l < k$ ) を満たすとき、 $p$  を  $k$  周期点とよぶ。ただし、 $f^k$  は  $f$  の  $k$  回合成写像である。周期点の系列  $\{f(p), \dots, f^k(p)\}$  を周期軌道とよぶ。周期点ではない初期値がある周期軌道に落ち込むとき、その初期値を  $E$  周期点とよぶ。周期軌道の乱雑さは、以下の絶対値自己相関で特徴づけられる：

$$R_{xx}(\tau) = \frac{1}{T} \left| \sum_{t=0}^{T-1} p(t)p(t-\tau) \right| \quad (3)$$

ただし、 $T$  は周期であり、 $p(t)$  は  $x_n$  を 0.5 をしきい値として 2 値化した系列である。ある Dmap が与えられたとき、それが呈する周期軌道の中で、最も周期の長いものを対象とし、(1) 周期、(2) 周期軌道に落ち込む  $E$  周期点数 (#EPP)、(3) 絶対値自己相関の 2nd Peak の 3 つで特徴づけることにする。表 1 に  $1.90 \leq a \leq 1.98$  の 9 つの Dmap の特徴量を示す。カットマップのカオスが、様々な周期軌道に複雑に変化していることがわかる。




図 1 Dmap の例 ( $N=64$ ). (a)  $a = 1.90$ , 5 周期. (b)  $a = 1.97$ , 12 周期.

表 1 Dmap の特徴量

$a$	周期	#EPP	2nd Peak
1.90	5	56	0.60
1.91	14	19	0.43
1.92	6	28	0.33
1.93	6	55	0.33
1.94	8	25	0.50
1.95	8	9	0.50
1.96	12	28	0.67
1.97	12	0	0.33
1.98	6	36	0.33

## 3 むすび

簡素な Dmap の呈する周期軌道を 3 つの特徴量を用いて考察した。周期軌道の詳細な分類などが課題である。

## 参考文献

- [1] Yamaoka, Horimoto, Saito, Proc. ICANN (2014) 73.
- [2] Kijima, Saito, Proc. NOLTA (2022) 271.

# 並列化降圧コンバータの2目的最適化について

On Biobjective Optimization of Paralleled Buck Converter

澁谷 晃誠<sup>1</sup>  
Kosei Shibuya

飯塚 寛人<sup>1</sup>  
Hirotto Iizuka

沼田 龍之介<sup>1</sup>  
Ryunosuke Numata

齋藤 利通<sup>1</sup>  
Toshimichi Saito

法政大学 理工学部 電気電子工学科<sup>1</sup>

Electrical and Electronics Department, Faculty of Science and Engineering, Hosei University

## 1 あらまし

バックコンバータの区分定数モデルを対象とし、効率と安定性に関する2目的最適化問題を考察する。

## 2 本論

図1に並列化バックコンバータの区分定数回路モデルを示す。スイッチ  $S_j$ 、ダイオード  $D_j$  ( $j = 1, 2$ ) は、State 1 ( $S_j = \text{ON}, D_j = \text{OFF}$ ) か State 2 ( $S_j = \text{OFF}, D_j = \text{ON}$ ) のいずれかをとる。State 1 ではインダクタ電流  $i$  は増加し、 $t = nT$  となると State 2 に切り替わる。State 2 ではインダクタ電流  $i$  は減少し、しきい値  $i = I_-$  に達すると State 1 に切り替わる。回路の動作は次式で記述される。

$$L \frac{di_j}{dt} = \begin{cases} V_{in} - V_{out} & \text{State 1} \\ -V_{out} & \text{State 2} \end{cases} \quad (1)$$

以下の無次元化変数とパラメータを用いると

$$\tau = \frac{t}{T}, \quad x_j = \frac{i_j - I_-}{I_p - I_-}, \quad (2)$$

$$a = \frac{T}{L(I_p - I_-)}(V_{in} - V_{out}), \quad b = \frac{T}{L(I_p - I_-)}V_{out}$$

式 (1) は無次元化方程式に変換される

$$\frac{dx_j}{dt} = \begin{cases} a & \text{State 1} \\ -b & \text{State 2} \end{cases} \quad (3)$$

### スイッチングルール

$x_1$ : State 1  $\rightarrow$  State 2:  $\tau = n, x_1 > x_2$  の場合

$x_2$ : State 1  $\rightarrow$  State 2:  $\tau = n, x_2 > x_1$  の場合

$x_j, j = 1, 2$ : State  $\rightarrow$  State 1:  $x_j = X_-$  のとき。

図2に無次元化電流波形の例を示す。

パラメータ  $(a, b)$  の関数として2つの目的関数を定義する。目的関数1は不動点の安定性を評価する:  $F_1(a, b) = |\frac{a}{b}|$ 。目的関数2は効率に影響を与えるリップルを評価する:  $F_2(a, b) = (1 - \frac{a}{b}) \frac{2ab}{a+b}$ 。区分定数系では、これらの関数は、厳密解に計算できる [1]。図3に  $a = 0.5$  と固定した場合の目的空間上のパレートフロントを示す。

参考文献 [2] に基づきハードウェア実装した。測定結果を図4に示す。

## 3 むすび

並列化バックコンバータの区分定数モデルの2目的最適化問題を考察した。より詳細な解析が課題である。

### 参考文献

- [1] H. Iizuka and T. Saito, Proc. NOLTA (2022) 527.
- [2] T. Saito et al., IJBC (2007)




図1 並列化バックコンバータの区分定数回路モデル




図2 無次元化電流波形 ( $a = 0.5$ ) (a)  $b = 0.6, F_1 = 0.83, F_2 = 0.09$ , (b)  $b = 1, F_1 = 0.5, F_2 = 0.33$




図3 パレートフロント ( $a = 0.5$ )




図4 測定波形  $V_{out} = 1.12\text{V}, X_- = 1.12\text{V}, T = 0.9\text{ms}$ . (a)  $V_{in} = 4.16\text{V}$ , (b)  $V_{in} = 3.04\text{V}$ .

# 分岐増幅器を用いたシフトレジスタの提案

Proposal of Shift Register With Coupled Bidirectional Bifurcation Amplifiers

田中 宏哉  
Hiroya Tanaka

田所 幸浩  
Yukihiro Tadokoro

株式会社豊田中央研究所  
Toyota Central R&D Labs., Inc.

## 1 はじめに

Nanoelectromechanical systems(NEMSS)は、センサなどへの応用を目的として注目を集めている。また、微小な機械共振器における非線形振動の信号処理への応用が検討されている[1]。本報告では、分岐増幅器を結合したシフトレジスタを提案し、その動作をシミュレーションにより検証する[2]。

## 2 分岐増幅器を用いたシフトレジスタ

提案システムの動作検証のために、2段フリップフロップからなるシフトレジスタを考える。提案システムは接続されたふたつの分岐増幅器(BA、図1)からなる。 $m$ はBAのインデックスである。BAでは、上部と下部の各ブランチで振動振幅が大きく異なり、2値データ $\{1, 0\}$ に対応する状態を保持できる。状態 $d_m$ は閾値 $\xi$ に基づいて識別される。駆動力 $\beta_m$ の変化が十分に大きいとき、 $\beta_m$ は $\beta_{pm}$ または $\beta_{qm}$ を越えるため、BAの状態は初期のブランチから他のブランチに切り替わる。

このモデルとして以下の式で表されるダフィング振動子を考える。

$$\frac{dv_m}{d\tau} + \kappa_m v_m + j\Omega_m v_m - jv_m|v_m|^2 - j\gamma^{(m)} v_m |v_n|^2 = -j\sqrt{\beta_m} \quad (1)$$

ここで、 $v_m$ は振動子座標、 $\gamma^{(m)}$ は非線形係数、 $\beta_m$ は駆動力、 $\kappa_m$ は摩擦係数、 $\tau$ は時間、 $\Omega_m$ は離調係数である。式の簡略化のために(1)中の係数はスケールされている[1]。また、駆動力の周波数よりも高い周波数をもつ振動を無視した。なお、 $m = \{1, 2\}$ 、 $n = \{1, 2\}$ 、 $n \neq m$ である。

サンプリング周期を $T$ とすると、 $0 < \tau < T$ でのシステムの動作は、write-hold プロセス( $0 < \tau < T - T_s$ )とtransfer プロセス( $T - T_s < \tau < T$ )に分けられる。Write-hold プロセスでは、入力データによりBA#1の状態が更新され、その状態がブランチに保持される。次にtransfer プロセスでは、BA#1の状態をBA#2に転送する。

BA#1の駆動力は振幅変調されており、2値入力データ $d(i) \in \{1, 0\}$ に対応する離散化された振幅 $\beta_{1i} \in \{\beta_{1\uparrow}, \beta_{1\downarrow}\}$ をとる。ここで、 $i$ は入力データのインデックスである。BA#1の駆動振幅は、入力データ列 $d_{in} = \{d(1), d(2), \dots\}$ に応じて $T$ 毎に切り替わる。一方、BA#2の駆動力は周期的に切り替わる振幅 $\beta_2 \in \{\beta_{2\uparrow}, \beta_{2\downarrow}\}$ をとる。 $\beta_2$ は $d(i)$ に依存しない

め、BA#2の状態の切り替えに事前の情報を必要としない。

## 3 結果

図2に $d_{in} = \{1, 0, 1, 1, 0, 1, 0\}$ をBA#1に入力したときの振動振幅を示す。各BAの状態は閾値レベル $\xi$ に従って識別され、BA#1に保持されたデータは、サンプリング周期 $T$ の後にBA#2に転送されていることがわかる。

## 4 おわりに

結合された分岐増幅器で構成されるシフトレジスタの動作を確認した。今後の課題として、多段フリップフロップからなるシフトレジスタへの拡張が挙げられる。

## 参考文献

- [1] I. Mahboob et al., *Sci. Rep.* 4, 4448 (2014).  
[2] H. Tanaka and Y. Tadokoro, *IEEE Trans. Circuits Syst. II Express Briefs* 69, 1712 (2022).




図1 分岐増幅器。




図2  $|v_1|^2$  および  $|v_2|^2$ .  $\tau = 0$  の各BAの状態を0とした。パラメータは、 $\beta_{1\uparrow} = 0$ ,  $\beta_{1\downarrow} = 1.5$ ,  $\beta_{2\uparrow} = 0.7$ ,  $\beta_{2\downarrow} = 1.5$ ,  $\beta_{2\downarrow} = 0.4$ ,  $\kappa_1 = \kappa_2 = 0.4$ ,  $\Omega_1 = 2.0$ ,  $\Omega_2 = 2.8$ ,  $\gamma^{(1)} = \gamma^{(2)} = 0.4$ ,  $T_s = 0.1T$ である。

# アイトラッカーの欠損値を用いた注意欠陥・多動性障害の瞬き頻度の分析

Analysis of Blink Frequency in Attention Deficit Hyperactivity Disorder Using Eye Tracker Missing Values

上野歩<sup>1</sup> 関口雅也<sup>1</sup> 信川創<sup>1,2</sup> 白間綾<sup>2</sup> 高橋哲也<sup>3</sup> 戸田重誠<sup>3,4</sup>  
Ayumu Ueno Masaya Sekiguchi Sou Nobukawa Aya Shirama Tetsuya Takahashi Shigenobu Toda  
千葉工業大学<sup>1</sup> 国立精神・神経医療研究センター<sup>2</sup> 金沢大学<sup>3</sup> 昭和大学<sup>4</sup>

## 1 はじめに

注意欠陥・多動性障害 (ADHD) は、不注意、衝動性、多動性を特徴とする神経発達症群の1つであり、早期診断と適切な介入により心理的・社会的な不適応を防止することができる。そのため、現在の間診を主体とする ADHD の診断をサポートする生物学的指標の確立が求められる。ADHD は、ドーパミン作動性およびノルアドレナリン作動性神経伝達の調節不全がその神経基盤である。そして、安静時の瞬きの頻度は前者の神経基盤と関連する。

先行研究では、持続的な注意や衝動性の機能を評価するための Continuous Performance Test (CPT) の1つである視覚 CPT を典型発達 (TD) と ADHD 間で行なった結果、TD よりも ADHD の方が瞬きの頻度が高い傾向が見られた [1]。この瞬きの頻度の違いは、TD が視覚情報を遮断しないために瞬きを抑制する能力が高い一方で、ADHD はその能力が低いため瞬きを抑制できなかったと考えられている [1]。したがって、瞬きの抑制が必要ないと予想される聴覚 CPT を行った際の瞬きの頻度は、ドーパミンに関連した内的な神経活動がより純粋に反映されると考えられる。そこで本研究ではこの点に着目し、視覚刺激のない聴覚 CPT を行なった際の成人 TD と成人 ADHD 間の瞬きの頻度を比較する。

## 2 手法

本研究の実験は、1964年のヘルシンキ宣言で規定された倫理基準に従って行われ、昭和大学の研究倫理委員会によって承認された。被験者は、成人 TD 23名 (内男性 10名、年齢  $35.5 \pm 1.7$  歳) と成人 ADHD 患者 17名 (内男性 8名、年齢  $31.7 \pm 2.0$  歳) で構成された。また、成人 ADHD 患者 1名は測定不良のため除外された。

聴覚 CPT では、標準音 (880Hz,  $p = 0.2$ ) と非標準音 (800Hz,  $p = 0.8$ ) が使用され、標準音の場合のみ速やかにボタンを押すよう指示された。課題中は、画面中央の白線領域を注視するよう指示された。各ブロックでは、音を 250ms 間提示した後、ランダムな刺激間隔 (3-5sec) が設けられ、連続で 100 回試行した。各ブロック間には短い休憩が設けられ、全体で 3 ブロック行なった。

瞳孔径は、サンプリング周波数 300Hz の遠隔型アイトラッカー (Tobii TX300) で測定し、音が提示された後の 3 秒間のデータを使用した。瞬きの持続時間である 100-400ms の間を瞬きとし、各ブロックの 1 秒あたりの瞬きの頻度を算出した。

瞬きの頻度について、被験者間因子を群 (TD, ADHD),

被験者内因子を各ブロック (1-3) とする反復測定分散分析を行い、有意な因子に対しては事後  $t$  検定を行なった。各検定における有意水準は 5% 未満とし、自由度の調整には Greenhouse-Geisser 法を使用した。

## 3 結果

各ブロックにおける TD 群と ADHD 群の 1 秒あたりの瞬きの頻度を図 1 に示す。群×ブロックの交互作用が有意となったため ( $F = 4.401, p = 0.021$ )、各ブロックに対して事後  $t$  検定を行なった。1 ブロックでは、TD 群は ADHD 群よりも瞬きの頻度が有意に高かった ( $p = 0.03$ )。




図 1 各ブロックの TD 群と ADHD 群の瞬きの頻度。

## 4 おわりに

本研究では、聴覚 CPT 中の TD 群と ADHD 群の瞬きの頻度を評価した。ドーパミンは運動機能や意欲、快感に関与し、瞬きの頻度とドーパミン量は比例する。このことから、1 ブロックでは TD 群より ADHD 群の方がドーパミン量が少ないことが示唆され、これは ADHD の神経基盤と一致する。また、視覚 CPT の先行研究とは異なり、TD 群は ADHD 群よりも瞬きの頻度が高かった [1]。これは、視覚刺激のない聴覚 CPT では瞬きが抑制されず、ドーパミンに関連した内的な神経活動が瞬きの頻度に直接反映されたと考えられる。

これらの発見は、瞬きに基づく ADHD の診断をサポートする生物学的指標の確立に寄与する可能性がある。

## 参考文献

[1] M Fried et al., "ADHD subjects fail to suppress eye blinks and microsaccades while anticipating visual stimuli but recover with medication," Vision research, vol.101, pp.62-72, 2014.

## 謝辞

本研究は JSPS 科研費 JP22K12183, JP23K03024, JP23K06983, JP23K07022, の助成を受けたものである。

# 離散力学系より得られる時系列データおよびパラメータを学習した Extreme learning machine に基づく分岐解析手法

Bifurcation analysis based on Extreme learning machine trained on time-series datasets and parameters of a discrete system

加藤海渡<sup>1</sup>  
Kaito Kato

伊藤佳卓<sup>2</sup>  
Yoshitaka Itoh

高坂拓司<sup>1</sup>  
Takuji Kousaka

中京大学<sup>1</sup>  
Chukyo University

北海道科学大学<sup>2</sup>  
Hokkaido University of Science

## 1 まえがき

分岐とは、パラメータに応じて系の定性的性質が変化する現象であり、分岐解析は工学分野における適切なパラメータ設計に寄与する。以下、実環境に対する分岐解析の適用に有効な手段として、ニューラルネットワーク (NN) に基づく分岐解析手法について考える。

先行研究 [1] は Extreme learning machine (ELM) [2] に基づく分岐解析手法を提案し、NN に時系列データを学習させるのみで、元の系の分岐解析を実現している。しかし、学習する時系列データのパラメータ (真のパラメータ) を未知としたため、学習済み NN のパラメータ空間と真のパラメータ空間は対応しない。

一方、本研究は真のパラメータを既知とし、両者のパラメータ空間が対応する場合に注目する。その代表的な手法としては、NN を用いて時系列データとパラメータを同時に学習する手法が挙げられ、学習済み NN は真のパラメータ空間における系の定性的性質を高精度で再現している [3]。しかし、NN を用いた分岐解析手法は見当たらない。そこで、本研究は実環境への分岐解析の適用を念頭に、離散力学系の時系列データおよびパラメータを学習した ELM に基づく分岐解析手法を提案する。

## 2 Extreme learning machine (ELM)

ELM は 3 層のフィードフォワード型 NN であり、その出力は次の離散力学系で表される。

$$\mathbf{x}(k+1) = \mathbf{f}(\mathbf{x}(k), \boldsymbol{\lambda}) = \boldsymbol{\beta} \cdot \mathbf{h}(\mathbf{x}(k), \boldsymbol{\lambda}) \quad (1)$$

ここで、 $\mathbf{x}(k) \in \mathbf{R}^N$  は時刻  $k$  における状態、 $\boldsymbol{\beta} \in \mathbf{R}^{N \times M}$  は出力層の結合荷重、 $\mathbf{h} \in \mathbf{R}^M$  は中間層の出力を意味し、 $N$  は入出力の次元数、 $M$  は中間層のニューロン数をそれぞれ表す。中間層の出力  $\mathbf{h}$  は次式で記述できる。

$$\mathbf{h} = \frac{\zeta}{1 + e^{-\rho \cdot \mathbf{z}}} - \sigma; \quad \mathbf{z} = (\mathbf{W} \cdot [\mathbf{x}(k)^\top, \boldsymbol{\lambda}^\top]^\top + \mathbf{b}) \quad (2)$$

$\mathbf{h}$  はシグモイド関数を表し、式中の  $\mathbf{z} \in \mathbf{R}^M$  における各要素に対して演算を行う。また、本研究で扱う ELM は  $[\mathbf{x}(k)^\top, \boldsymbol{\lambda}^\top]^\top = [x_1(k), \dots, x_N(k), \lambda_1, \dots, \lambda_P]^\top \in \mathbf{R}^{(N+P)}$  のように、状態  $\mathbf{x}(k)$  とパラメータ  $\boldsymbol{\lambda} \in \mathbf{R}^P$  を同時に入力することで、任意の  $\boldsymbol{\lambda}$  における出力を実現している。パラメータの次元数  $P$  とシグモイド関数のパラメータ  $\zeta, \sigma, \rho$  は学習する時系列データに応じて決定する。 $\mathbf{W} \in \mathbf{R}^{M \times (N+P)}$  および  $\mathbf{b} \in \mathbf{R}^M$  は中間層の結合荷重とバイアスをそれぞれ表し、これらは区間  $[-1, 1]$  の一様乱数に固定する。また、 $\boldsymbol{\beta}$  は疑似逆行列を用いた学

習則に基づき最適化される。

## 3 学習済み ELM に基づく分岐解析手法

式 (1) の学習済み ELM が表す離散力学系について考える。初期値  $\mathbf{x}(k)$  を満たす解を次式に示す。

$$\mathbf{x}(k+1) = \varphi(1, \mathbf{x}(k), \boldsymbol{\lambda}) \quad (3)$$

$m$ -周期点にみられる局所分岐点は、 $m$ -周期点条件と特性方程式を連立させた式 (4) より導出する。

$$\left[ \det \left( \frac{\partial \varphi}{\partial \mathbf{x}(k)}(m, \mathbf{x}(k), \boldsymbol{\lambda}) - \mu \mathbf{I}_N \right) \right] = 0 \quad (4)$$

ここで、 $\mu$  は特性乗数を表す。式 (4) を Newton 法により解く場合、ELM から  $m$ -周期点に関する初期値とパラメータによる微分を導出する必要がある。以下、紙面の都合上 1 階微分  $\partial \varphi / \partial \mathbf{x}(k)(m, \mathbf{x}(k), \boldsymbol{\lambda})$  のみ説明する。

$$\frac{\partial \varphi}{\partial \mathbf{x}(k)}(m, \mathbf{x}(k), \boldsymbol{\lambda}) = \prod_{r=1}^m \frac{\partial \varphi}{\partial \mathbf{x}(k+m-r)}(1, \mathbf{x}(k+m-r), \boldsymbol{\lambda}) \quad (5)$$

右辺の  $\mathbf{x}(k+m-r)$  による微分は、式 (1) および式 (2) に示す ELM より次式で導出できる。

$$\frac{\partial \varphi_i}{\partial x_l(k+m-r)}(1, \mathbf{x}(k+m-r), \boldsymbol{\lambda}) = - \sum_{j=1}^M W_{j,l} \beta_{i,j} \frac{\rho(h_j + \sigma - \zeta)(h_j + \sigma)}{\zeta} \quad (6)$$

各変数の下付き文字  $i, j, l$  はベクトルおよび行列の要素番号を表し、 $i, l \in [1, N]$ 、 $j \in [1, M]$  である。 $\mathbf{x}(k)$  による 2 階微分および  $\boldsymbol{\lambda}$  による微分も同様に計算可能。

## 4 おわりに

本研究は、離散力学系の時系列データとパラメータを同時に学習した ELM に基づく分岐解析手法を提案した。

### 参考文献

- [1] Y. Itoh, *et al.*, Nonlinear Theory and Its Applications, IEICE, Vol. 10, No. 2, pp. 268–278, 2019.
- [2] G. B. Huang, *et al.*, Neurocomputing, Vol. 70, No. 1-3, pp. 489–501, 2006.
- [3] M. Roy, *et al.*, Chaos, Vol. 32, No. 10, pp. 101104, 2022.

# Hebb 則と時空間学習則のパターン分離能力の比較

Comparison of pattern discrimination ability between the Hebbian learning and the spatiotemporal learning rules

塚本陽太<sup>1</sup>      塚田啓道<sup>2</sup>      塚田稔<sup>3</sup>      池口徹<sup>1</sup>  
 Yota Tsukamoto      Hiromichi Tsukada      Minoru Tsukada      Tohru Ikeguchi  
 東京理科大学<sup>1</sup>      中部大学 AI 数理データサイエンスセンター<sup>2</sup>      玉川大学 脳科学研究所<sup>3</sup>

## 1 はじめに

塚田らは、海馬を用いた生理学実験により、シナプス後ニューロンの発火がシナプス可塑性に寄与しない時空間学習則 (STLR) を発見している [1]. シナプス前ニューロンとシナプス後ニューロンの双方の発火タイミングがシナプス可塑性に寄与する Hebb 則 [2] とは異なり, STLR は類似した入力を識別するパターン分離能力に優れているとされている [3, 4]. 本稿では, 入力パターン類似度を変化させた場合に, パターン分離能力がどのように変化するかを, Hebb 則, Hebb± 則, STLR を対象として調査したので報告する.

## 2 モデル

本稿では, 入力層と出力層がともに  $N (= 120)$  個の形式ニューロンからなる全結合のフィードフォワードネットワークを用いた. 離散時刻  $t_n$  における  $j$  番目のシナプス前ニューロンと  $i$  番目のシナプス後ニューロンの出力を  $x_j(t_n), y_i(t_n), (i, j = 1, \dots, N)$  とし, 1 ならば発火, 0 ならば静止とする. また,  $j-i$  間のシナプス荷重を  $w_{ij}(t_n)$  とする. ニューロンの内部状態および出力は式 (1), 式 (2) により決定される. ここで,  $\eta$  は発火の閾値である.

$$s_i(t_n) = \sum_{j=1}^N w_{ij}(t_n) x_j(t_n) \quad (1)$$

$$y_i(t_n) = \begin{cases} 1 & s_i(t_n) \geq \eta \\ 0 & s_i(t_n) < \eta \end{cases} \quad (2)$$

Hebb 則, Hebb± 則, STLR はそれぞれ式 (3), 式 (4), 式 (5) で表される.

$$w_{ij}(t_{n+1}) = w_{ij}(t_n) + \Delta w x_j(t_n) y_i(t_n) \quad (3)$$

$$w_{ij}(t_{n+1}) = \begin{cases} w_{ij}(t_n) + \Delta w, & x_j(t_n) = y_i(t_n) = 1 \\ w_{ij}(t_n), & x_j(t_n) = y_i(t_n) = 0 \\ w_{ij}(t_n) - \Delta w, & \text{otherwise} \end{cases} \quad (4)$$

$$w_{ij}(t_{n+1}) = \begin{cases} w_{ij}(t_n) + \Delta w, & J_{ij}(t_n) \geq \theta_1 \\ w_{ij}(t_n), & \theta_2 < J_{ij}(t_n) < \theta_1 \\ w_{ij}(t_n) - \Delta w, & J_{ij}(t_n) \leq \theta_2 \end{cases} \quad (5)$$

ここで,  $\Delta w$  は学習率,  $\theta_1, \theta_2$  はそれぞれ長期増強, 長期減弱のパラメータである. また, 式 (5) の  $J_{ij}(t_n)$  はニューロン  $i$  への入力の同時性の時間履歴であり, 式 (6) および式 (7) で定義される [3]. ここで,  $\lambda$  は時定数であり, 本稿では  $\lambda = 223[\text{ms}]$  とした [5].

$$J_{ij}(t_n) = \sum_{m=0}^n I_{ij}(t_m) \exp\left(-\frac{t_n - t_m}{\lambda}\right) \quad (6)$$

$$I_{ij}(t_n) = w_{ij}(t_n) x_j(t_n) \sum_{k=1, k \neq j}^N w_{ik}(t_n) x_k(t_n) \quad (7)$$

## 3 パターン分離能力の評価

入力系列として, 0 と 1 が 60 ビットずつランダムに並ぶ 120 ビットの系列を 5 個生成した. この際, 各系列間のハミング距離が常に同じ値  $D$  となるように調整している. 系列の  $j$  番目の要素はニューロン  $j$  の発火の有無を表す.

5 個の系列を並び替えた 120 通りの系列を, 同じ初期状態のニューラルネットワークに  $n = 1, 2, \dots, 5$  において与えることで学習させた後, 出力取得用の系列を与えることで出力を得た. 得られた 120 個の出力系列のうち, 異なる出力系列の個数によりパターン分離能力を評価した. 入力系列のハミング距離を  $D = 4, 8, \dots, 40$  と変化させたときの各学習則のパターン分離能力の変化の様子を図 1 に示す ( $\Delta w = 1.0$ ).




図 1 入力系列のハミング距離  $D$  とパターン分離能力の関係. エラーバーは 100 回試行による平均値からの標準偏差の範囲を表す.

図 1 より, Hebb 則と Hebb± 則は入力系列のハミング距離  $D$  に関係なくパターン分離能力が低い. 一方, STLR はパラメータによって傾向が大きく異なることが分かる.  $(\theta_1, \theta_2) = (10, 1)$  ではパターン分離能力が極めて低い.  $(\theta_1, \theta_2) = (30, 16)$  では入力系列のハミング距離  $D$  の増加に伴いパターン分離能力が低下するが,  $(\theta_1, \theta_2) = (22, 2)$  では向上する. 以上の結果は, STLR がパラメータに応じて特定の入力系列のハミング距離を検出できることを示唆する. 今後は, 学習における閾値コントロールが導入された生理学実験の結果 [6] なども考慮して, この仮説の検証を行う予定である. 本研究の一部は, JSPS 科研費 JP20H04246, JP20H00596, JP21H03514, JP22K18419 及び東北大学電気通信研究所共同プロジェクト研究 R05/A19, R05/B13 の助成を受けた.

## 参考文献

- [1] M. Tsukada et al., *Neural Networks*, 9(8), 1357–1365, 1996.
- [2] D. O. Hebb, Oxford: Wiley, 1949.
- [3] M. Tsukada and X. Pan, *Biological Cybernetics*, 92(2), 139–146, 2005.
- [4] H. Tsukada and M. Tsukada, *Frontiers in Systems Neuroscience*, 15, 624353, 2021.
- [5] T. Aihara et al., *Hippocampus*, 7(4), 416–426, 1997.
- [6] E. Sugisaki et al., *Brain Research*, 1649, 44–52, 2016.

# カオスニューロダイナミクスを用いた切替機構の隠れマルコフモデルへの置換

Replacing a Switching Mechanism Using Chaos Neurodynamics with One Using a Hidden Markov Model

橘 俊宏<sup>1</sup>  
Toshihiro Tachibana

安達雅春<sup>2</sup>  
Masaharu Adachi

湘南工科大学情報学部情報学科<sup>1</sup>  
Department of Informatics, Faculty of Informatics, Shonan Institute of Technology  
東京電機大学工学部電気電子工学科<sup>2</sup>

Department of Electrical and Electric Engineering, School of Engineering, Tokyo Denki University

## 1 はじめに

筆者らは文献 [1, 2] で提案する手法を元に非対称巡回セールスマン問題（非対称 TSP）や、多目的最適化問題（MOP）などの最適化問題の解法アルゴリズムを提案し、カオスニューロダイナミクスの有効性を確認するため文献 [3] や文献 [4] に示すようにカオスニューロダイナミクスを用いた切替機構を隠れマルコフモデルへ置換することを試みている。

本稿では、これまで行ってきた隠れマルコフモデルへの置換を総括すると共に、これまでの研究により明らかになった点についてまとめる。

## 2 非対称巡回セールスマン問題の場合

複数の地点交換法をカオスニューロダイナミクスにより切り替えて使用する手法 [2] に対しては、表 1 のとおり地点交換法切替の遷移確率から作成した HMM による切替に置換した場合、カオスニューロダイナミクスにより地点交換法を切り替えて使用する場合と同等の性能を有するアルゴリズムとなった。

表 1 非対称 TSP での実験結果 (gap)

	p43	dc112	rbg403	rbg443
非対称度	0.442	0.151	0.923	0.925
CNN[2]	<b>0.0006</b> ± 0.003	<b>0.1</b> ± 0.1	<b>0</b> ± 0	<b>0</b> ± 0
使用確率	0.07 ± 0.06	0.2 ± 0.1	0.03 ± 0.08	0.1 ± 0.1
遷移確率	0.01 ± 0.003	<b>0.1</b> ± 0.1	<b>0</b> ± 0	0.02 ± 0.06

このとき、大域最適解に到達した試行について手法の遷移確率を比較したところ、類似の結果が得られた。

## 3 多目的最適化問題の場合

複数の粒子群最適化法アルゴリズムをカオスニューロダイナミクスにより切り替えて使用する手法 [1] に対しては、表 2 のとおりアルゴリズムの使用確率から作成した HMM、アルゴリズム間の遷移確率から作成した HMM のどちらに置換した場合でも、問題により同等の性能になる場合とそうでない場合に分かれた。

表 2 MOP での実験結果 (GD)

	ZDT3	ZDT4
CNN	<b>0.00120</b> ± 0.00176	<b>0.00210</b> ± 0.00093
使用確率	0.00194 ± 0.00263	0.00426 ± 0.00162
遷移確率	<b>0.00125</b> ± 0.00131	0.04457 ± 0.01866

ZDT3 では HMM 化しても CNN 同程度となったが ZDT4 では大きく劣る結果となった。そこで最良の試行

と 2 番目の試行の手法の遷移確率を求めたところ表 3, 4 のようになった。ZDT4 では試行により主で使用する手法をはじめ大きく異なる遷移確率が求められた。

表 3 ZDT3 での手法の使用割合

	試行 a	試行 b
GD	<b>0.00074</b>	<b>0.00076</b>
MOPSO → MOPSO	0.000660	0
MOPSO → OMOPSO	0	0.000007
MOPSO → SMPSO	0.000020	0
OMOPSO → MOPSO	0.000007	0
OMOPSO → OMOPSO	0.000040	0.000033
OMOPSO → SMPSO	0.0000133	0.000007
SMPSO → MOPSO	0.000133	0
SMPSO → OMOPSO	0.000133	0
SMPSO → SMPSO	<b>0.999227</b>	<b>0.999947</b>

表 4 ZDT4 での手法の使用割合

	試行 a	試行 b
GD	<b>0.00087</b>	<b>0.00096</b>
MOPSO → MOPSO	<b>0.982467</b>	0.005547
MOPSO → OMOPSO	0.000287	0.000287
MOPSO → SMPSO	0.000053	0.000107
OMOPSO → MOPSO	0.000307	0.000293
OMOPSO → OMOPSO	0.009740	<b>0.977620</b>
OMOPSO → SMPSO	0.000060	0.000087
SMPSO → MOPSO	0.000040	0.000100
SMPSO → OMOPSO	0.000073	0.000100
SMPSO → SMPSO	0.006967	0.015853

この結果より MOP については試行毎に解空間の構造が大きく異なっており、その時々に対応する機構が必要と考えられる。

## 4 おわりに

非対称 TSP と MOP を例に CNN を HMM への置換を試みた。その結果、MOP では問題によっては試行毎に解空間が大きく異なるため、特定の試行から HMM を構築しても成功する場合と失敗する場合があることがわかった。そのため MOP では、CNN による切替が有効だと考えられる。

## 参考文献

- [1] 橘俊宏ら, 信学技報, **111**(498), 51–56, 2012.
- [2] 橘俊宏ら, 信学技報, **117**(505), 61–66, 2018.
- [3] 橘俊宏ら, 信学技報, **122**(436), 81–84, 2023.
- [4] 橘俊宏ら, 信学技報, **122**(396), 6–11, 2023.

# ヒステリシスリザーバーコンピューティングの内部設計と性能向上

Internal Design and Performance Improvement of Hysteresis Reservoir Computing

横山賢太<sup>1</sup>  
Kenta Yokoyama

神野健哉<sup>1</sup>  
Kenya Jin'no

東京都市大学情報工学部知能情報工学科<sup>1</sup>  
Department of Intelligent Systems, Faculty of Information Technology, Tokyo City University

## 1 まえがき

リザーバーコンピューティング (RC) の記憶容量や表現能力といったモデルの性能を向上させるためには内部構造を適切に設計する必要がある。一方記憶容量と表現能力にはトレードオフの関係性があり、両者の性能を同時に良くすることは困難である。本稿では複雑な振る舞いを行う HN をリザーバー層に用いたヒステリシスリザーバーコンピューティング (HRC)[1] の内部設計について検討を行い、従来よりもどの程度性能が向上するのかを検討する。

## 2 ヒステリシスリザーバーコンピューティング

RC は入力層, 中間層 (リザーバー層), 出力層の 3 層から構成され, リザーバー層にリザーバーニューロンを設定する。また入力層とリザーバー層間の重み, リザーバー層内の重みは初期状態のまま固定し, リザーバー層と出力層間の重みのみを学習している。HRC は RC に複雑な振る舞いを行う HN を加えることで時系列データを表現しようとするモデルである。このとき HN は (1) 式で示される区分線形微分方程式に従って動作する。

$$\begin{cases} \lambda_i \frac{dx_i(t)}{dt} = -x_i(t) + \sum_{j=1}^n w_{ij} y_j(t) \\ y_i(t) = h(x_i(t)) = \begin{cases} 1 & \text{if } x_i(t) \geq -1, \\ -1 & \text{if } x_i(t) \leq 1 \end{cases} \end{cases} \quad (1)$$

ここで  $\lambda_i$  は時定数,  $h(x_i(t))$  は区分線形ヒステリシス,  $x_i(t)$  は内部状態変数,  $w_{ij}$  はリザーバー層内の HN 間の重み,  $y_j(t)$  は HN の出力を表す。また HN は平衡点に向かって移動し, もし HN の内部状態変数が閾値に到達すると図 1 のように出力が切り替わる。




図 1 ヒステリシスニューロンの振る舞い

このとき平衡点は  $p_i(t) = \sum_{j=1}^n w_{ij} y_j(t)$  であり,  $p_i(t) y_i(t) < -1$  であれば HN の出力が切り替わる可能性がある。切り替わる可能性のある出力の切り替わり時間は厳密解に基づく高速アルゴリズム [2] で算出できる。

## 3 実験

時定数が一定でない場合に Mackey-Glass 方程式のような複雑な振る舞いの時系列データの予測ができるか検証する。結果を図 2 に示す。リザーバー層内の HN は 163 個とした。




図 2 入力信号と予測結果の比較

図 2 から入力信号とシステムの出力結果が似た振る舞いであると確認できるが, HRC 内の設計のみでは予測が難しく, FORCE 学習 [3] を用いてリザーバー層と出力層間の重みの調整が必要であった。FORCE 学習で用いるハイパーパラメータも予測性能に大きく影響するため, 適切な値を用いる必要がある。

## 4 結論

時定数の設定と FORCE 学習によって複雑な時系列データの振る舞いを学習できた。今後他のデータに対しても予測できるモデルを設計するとともに, 入力層を追加したモデルで実際の時系列データの予測を行う。

## 謝辞

本研究の一部は JSPS 科研費 23K11266, 23H03387, 東北大学電気通信研究所共同プロジェクト研究, 東京都市大学重点推進研究未来知能ユニットの助成によるものです。

## 参考文献

- [1] T.Saito, K.Jin'no, "Consideration of the output series generated by hysteresis reservoir computing," IEICE NOLTA, vol.13, no.2, pp.258-263, 2022.
- [2] K.Jin'no, T.Saito, "Analysis of Periodic Attractor in a Simple Hysteresis Network," IEICE Trans., vol.E79-A, pp.873-882, 1996.
- [3] D.Sussillo, L.F.Abbott, "Generating Coherent Patterns of Activity from Chaotic Neural Networks," Neuron 63, 544-557, 2009.

# 画像式光電脈波のデータ縮小が予測可能性に及ぼす影響

## The Effect of Data Reduction on Predictability in Imaging Photoplethysmography

古賀 滉大<sup>1</sup> スヴィリドヴァニーナ<sup>1,2</sup>  
Kodai Koga Nina Sviridova

東京都市大学 情報工学部 知能情報工学科<sup>1</sup>

東京大学国際高等研究所ニューロインテリジェ  
ンス国際研究機構<sup>2</sup>

Faculty of Information Engineering, Department of  
Intelligent Systems, Tokyo City University

International Research Center for Neurointelligence,  
The University of Tokyo

### 1. はじめに

皮膚表面への光照射により、その反射光の量を測定し得られる脈波情報を、光電脈波 (Photoplethysmogram, 以下、PPG) という。PPG の計測は非侵襲であるため、スマートウォッチなどのウェアラブルデバイスで広く用いられ、健康管理などに利用されている。

一方で、画像式光電脈波 (imaging photoplethysmogram, 以下、iPPG) 法がある。これは LED ライトを光源、カメラを受光体とすることで、擬似的な PPG の計測装置を作り、皮膚表面を撮影した動画から、脈波を推定する方法である。

先行研究では、PPG はカオス信号であることが示されており [1]、PPG と iPPG のある種のダイナミクスの特性は類似性を示している [2]。しかし、iPPG のダイナミクスの特性のほとんどは、予測可能性を含め、まだ検証されていない。また、[3] で示されているように、PPG の測定に使用されるサンプリングレートは、PPG の動的特性の推定に影響を与える可能性がある。そこで本研究では、異なるビデオのフレームレート (Frame Per Seconds, 以下、FPS) で撮影した iPPG データにおける平均予測時間と解釈される再帰定量化解析の平均の対角線の長さ ( $L$ ) [4] を求め、FPS が iPPG データの予測可能性に及ぼす影響を検証する。

### 2. データ取得実験

iPPG データは健康な 20 代男性 3 名を対象に、第 6 世代 iPad mini を使用して 1920×1080 画素、240fps のスローモーションモードで右手の人差し指を撮影して取得した。撮影は 23°C の静かな部屋で行い、各被験者は 2 回、約 5 分間安静にした状態でデータを収集した。実験前には血圧と心拍数が正常であることを確認した。

### 3. 解析手法

動画から iPPG データを算出する手順について。まず動画をフレームに分割し、各フレームの ROI (Region of Interest) を指定する。次に、ROI の赤色チャンネルの平均値を計算する。得られた時系列データに対し、移動平均フィルターを適用し、動画の前後 10% を削除する。

1 次元時系列データからダイナミクスの特徴を抽出するために遅延座標系の再構成を行う。これは時系列データを元に、各時点で多次元のベクトルを作成

する方法で、遅れ時間ごとにデータ点を選び、それらを組み合わせて新たな多次元の時系列データを生成する。

リカレンスプロットは、時系列データの周期性や動的構造を視覚化することができる。データ点間の距離が閾値以下であれば点を打ち、そうでなければ点を打たないことで、時系列の繰り返しやパターンを平面上に表現することができる。平均の対角線の長さ  $L$  は、リカレンスプロット上の対角線の長さの平均値を表す。システムの平均予測時間を評価する事ができる。

### 4. 解析結果

以下の図 1 は FPS を変化させたとき、予測可能性  $L$  の値がどのように変わるのかを示したグラフである。赤い点線が 5 つのデータの  $L$  値の平均値である。  $n\Delta t$  ( $n = 1, 2, \dots, 10$ ) としたとき、  $n = 1$  のとき 188FPS であり、  $n = 10$  のとき 18FPS である。図 1 を見ると、  $n > 8$  (23FPS) で  $L$  値が収束している事がわかる。




図 1: フレームレートと平均予測時間  $L$  の関係

### 5. まとめ

図 1 より、サンプリング間隔を  $\Delta t$  としたとき、  $\Delta t$  を増加させると、  $L$  値が減少することがわかった。

また、  $n\Delta t$  としたとき、  $n = 1$  から  $n = 2$  にかけて大幅に  $L$  値が減少している事がわかった。今後は被験者を増やし、  $L$  値の平均値にエラーバーを表示させるなどすることで、FPS を変化させたとき  $L$  値がどのように変わるのかを詳しく分析したい。

本研究の一部は、JSPS 科研費 (No. JP19K14589, JP20H05921) の援助を受けて行われた。

### 参考文献

- [1] N. Sviridova et al., Chaos, Solitons & Fractals, 116, 157–165, 2018.
- [2] 中山裕文 他, 信学技報, 122, NLP-436, 95–99, 2023.
- [3] N. Sviridova et al., Proceedings of BIBE 2022, 135–138, 2022.
- [4] N. Marwan et al., Physics Reports, 438, 237–329, 2007.